

Rozdelenia pravdepodobnosti odhadcov variančných parametrov vo FDSLRLM

Robust 2018

Andrej Gajdoš
Martina Hančová

Prírodovedecká fakulta UPJŠ v Košiciach

25.1.2018

Kriging

- časové rady (**ČR**)
- modelovanie pomocou dostatočne všeobecnej a širokej triedy lineárnych regresných modelov (**LRM**)
- v našom výskume trieda **FDSLRLM** (Štulajter 2002-2003)
- hlavná myšlienka – nájdenie najlepšej lineárnej nevychýlenej predikcie (**BLUP**)
- rôzne výskumné problémy: modelovanie, odhadovanie variančných parametrov, vplyv odhadov na prediktory, kvalita predikcií, ...

Čím sa zaoberáme

Definícia(FDSLRLM)

Model časového radu $X(\cdot)$ nazývame lineárny regresný model s konečným diskretným spektrom (FDSLRLM), ak $X(\cdot)$ má tvar

$$X(t) = \sum_{i=1}^k \beta_i f_i(t) + \sum_{j=1}^l Y_j v_j(t) + w(t); \quad t = 1, 2, \dots; k, l \in \mathbb{N}_0,$$

kde $\beta = (\beta_1, \beta_2, \dots, \beta_k)'$ z \mathbb{E}^k je vektor regresných parametrov,
 $\mathbf{Y} = (Y_1, Y_2, \dots, Y_l)'$ je náhodný vektor so strednou hodnotou $E\{\mathbf{Y}\} = \mathbf{0}$ a kovariančnou maticou $Cov\{\mathbf{Y}\} = \text{diag}(\sigma_j^2)$ z $\mathbb{E}^{l \times l}$ so $\sigma_j^2 \geq 0; j = 1, 2, \dots, l$,
 $f_i(\cdot); i = 1, 2, \dots, k$ a $v_j(\cdot); j = 1, 2, \dots, l$ sú reálne funkcie definované na \mathbb{E}^1 ,
 $w(\cdot)$ je biely šum nekorelovaný s \mathbf{Y} a s disperziou $D\{w(t)\} = \sigma^2 > 0$.

Definícia a vlastnosti LCNE

- zavedenie všeobecnejšej triedy odhadcov – **lineárna kombinácia NE (LCNE)** [▶ definícia NE](#)

Definícia (Lineárna kombinácia NE)

Nech platia predpoklady definície NE. Lineárnou kombináciou NE, v skratke LCNE, budeme rozumieť výraz v tvare

$$\sigma_j^{*2}(\mathbf{X}) = a\check{\sigma}_j^2(\mathbf{X}) + b\check{\sigma}^2(\mathbf{X}), \quad a, b \in \mathbb{E}^1$$

kde $\check{\sigma}_j^2(\mathbf{X})$, $\check{\sigma}^2(\mathbf{X})$ sú príslušné NE.

- doterajší MNŠ odhadcovia vo FDSLRLM – špeciálne prípady LCNE [▶ definícia DOOLSE, MDOOLSE](#)

Definícia a vlastnosti LCNE

Veta (vlastnosti LCNE)

Majme lineárnu kombináciu NE v tvare $\sigma_j^*(\mathbf{X}) = a\check{\sigma}_j^2(\mathbf{X}) + b\check{\sigma}^2(\mathbf{X})$, $a, b \in \mathbb{E}^1$. Potom tieto odhadcovia sú invariátne kvadratické formy s nasledujúcimi štatistickými vlastnosťami:

$$(i) E_{\nu}\{\sigma_j^*(\mathbf{X})\} = [b + aW_{jj}^{-1}]\sigma^2 + a\sigma_j^2$$

$$(ii) D_{\nu}\{\sigma_j^*(\mathbf{X})\} = 2a^2[\sigma_j^2 + \sigma^2W_{jj}^{-1}]^2 + \frac{2b^2}{n-k-1}\sigma^4$$

$$(iii) Cov_{\nu}\{\sigma_i^*(\mathbf{X}), \sigma_j^*(\mathbf{X})\} = 2ac[\sigma^2W_{jj}^{-1}]^2 + \frac{2bd}{n-k-1}\sigma^4;$$
$$\sigma_i^2(\mathbf{X}) = c\check{\sigma}_i^2(\mathbf{X}) + d\check{\sigma}^2(\mathbf{X}), i \neq j$$

$$(iv) MSE_{\nu}\{\sigma_j^*(\mathbf{X})\} = a^2W_{jj}^{-2}\sigma^4 + 2a^2[\sigma_j^2 + \sigma^2W_{jj}^{-1}]^2 + \frac{2b^2}{n-k-1}\sigma^4$$

- dôkaz s využitím známych vlastností NE (Hančová, 2008) a operátorov $E\{.\}$, $D\{.\}$, $Cov\{.\}$

Definícia a vlastnosti LCNE

Veta (pravdepodobnostné rozdelenie LCNE)

Nech \mathbf{X} je pozorovanie gaussovského FDSLRLM. Potom LCNE s parametrami $a, -b$ ($a, b > 0$) má rozdelenie $GDD(\alpha_1, \beta_1, \alpha_2, \beta_2)$ s nasledovnými parametrami

$$\alpha_1 = \frac{1}{2}, \beta_1 = \frac{1}{2a(\sigma^2 \mathbf{W}_{jj}^{-1} + \sigma_j^2)}, \alpha_2 = \frac{n-k-l}{2}, \beta_2 = \frac{n-k-l}{2b\sigma^2}.$$

▸ GDD

- dôkaz s využitím lemy a projekčnej teórie v maticových (Hilbertových) priestoroch

Lema

Nech $\mathbf{X} \sim N(\mathbf{F}\beta, \Sigma)$ a spĺňa lineárny regresný model v tvare $\mathbf{X} = \mathbf{F}\beta + \varepsilon$, kde $E\{\varepsilon\} = 0$, $\text{Cov}\{\varepsilon\} = \Sigma$ a nech $\mathbf{X}'\mathbf{A}\mathbf{X}$ je invariálna kvadratická forma ($\mathbf{A}\mathbf{F} = 0$).

Potom $\mathbf{X}'\mathbf{A}\mathbf{X} \sim \Gamma\left(\frac{r(\mathbf{A})}{2}, \frac{1}{2c}\right)$ práve vtedy, keď $\mathbf{A}\Sigma\mathbf{A}\Sigma = c\mathbf{A}\Sigma$.

- rozdelenia MNŠ odhadcov (NE, MNE, DOOLSE, MDOOLSE) ako dôsledky vety [▸ ďalšie rozdelenia](#)

- ortogonálny FDSLRLM: $F'V = 0$, $V'V$ je diagonálna matica

Veta

V ortogonálnom FDSLRLM platia pre odhadcov variančných parametrov tieto vzťahy:

$$\text{DOOLSE} = \text{MINQUE}(I), \quad \text{MDOOLSE} = \text{MINQUE}(U,I).$$


- dôkaz s využitím maticovej algebry, projekčnej teórie v Hilbertových priestoroch
- rozdelenia pravdepodobnosti pre $\text{MINQUE}(I)$ a $\text{MINQUE}(U,I)$ vo FDSLRLM ako dôsledky našej vety

Numerické prístupy pre GDD

- tri spôsoby numerického výpočtu distribučnej funkcie GDD:
 - 1 numerická integrácia integrálu distribučnej funkcie
 - 2 numerická aproximácia pomocou váženej sumy χ^2 rozdelení
 - 3 Monte Carlo simulácie (Gajdoš, Hančová, Hanč 2017)
- aplikácia odvodenej teórie a navrhnutých numerických prístupov (problém výskytu záporných odhadov variancií)
- numerická/simulačná štúdiá založená na prevzatých dátach (Štulajter, Witkovský, 2004)
- pravdepodobnosti, kvantily, intervaly spoľahlivosti

Numerické prístupy pre GDD





- 24 hodinové pozorovanie X spotreby el. energie v obchodnom dome (Štulajter & Witkovský, 2004):



$$X_m = \alpha + \sum_{i=1}^m (\beta_i \cos \lambda_i t + \gamma_i \sin \lambda_i t) + \sum_{j=1}^{3-m} (Y_j \cos \lambda_j t + Z_j \sin \lambda_j t) + w(t); \lambda_i, \lambda_j \in \mathbb{E}^1, m \in \{0, 1, 2, 3\}$$

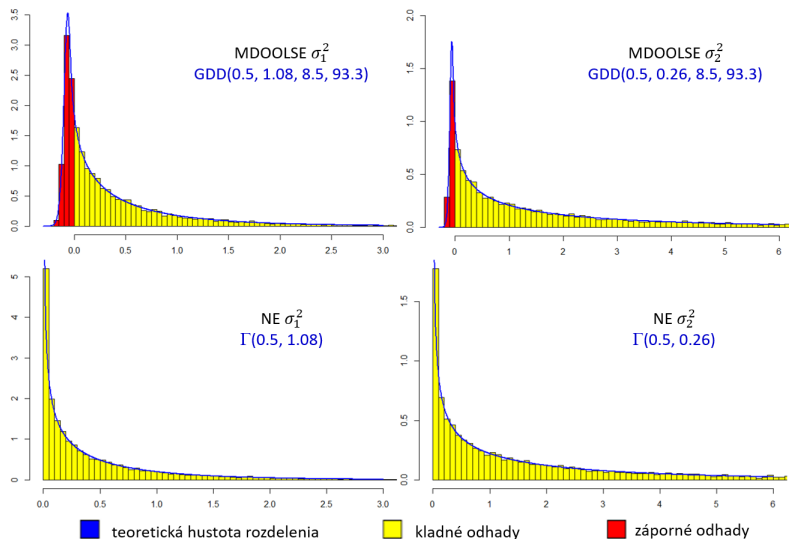
- štyri FDSLRLM dizajny na základe spektrálnej analýzy ČR (R Core Team, 2018)

Numerické prístupy pre GDD



skutočná hodnota variance v ■ nezáporné odhady väčšie ako v ■ nezáporné odhady menšie ako v ■ záporné odhady

Numerické prístupy pre GDD



Numerické prístupy pre GDD

| model | $m = 0$ | | $m = 1$ | | $m = 2$ | |
|--------------|---------|---------|---------|---------|---------|---------|
| odhad | DOOLSE | MDOOLSE | DOOLSE | MDOOLSE | DOOLSE | MDOOLSE |
| σ_1^2 | 0.073 | 0.075 | 0.124 | 0.135 | 0.299 | 0.337 |
| σ_2^2 | 0.065 | 0.067 | 0.159 | 0.173 | 0.148 | 0.168 |
| σ_3^2 | 0.131 | 0.135 | 0.313 | 0.337 | × | × |
| σ_4^2 | 0.168 | 0.173 | 0.155 | 0.168 | × | × |
| σ_5^2 | 0.328 | 0.337 | × | × | × | × |
| σ_6^2 | 0.164 | 0.168 | × | × | × | × |

Význam a prínos výsledkov

- zavedenie všeobecnejšej triedy odhadcov variančných parametrov vo FDSLRLM
- odvodenie momentových charakteristík a rozdelení pravdepodobnosti pre LCNE
- možnosť všeobecnejšie skúmať odhadcov i empirické prediktory vo FDSLRLM
- navrhnuté a implementované numerické prístupy pre GDD
- exaktná kvantifikácia problému výskytu záporných odhadov vo FDSLRLM

- Gajdoš, A., Hančová, M., Hanč, J. (2017).** *Kriging Methodology and Its Development in Forecasting Econometric Time Series*. Statistica: Statistics and Economy Journal, 97(1), 59–73.
- Hančová, M. (2008).** *Natural estimation of variances in a general finite discrete spectrum linear regression model*. Metrika, 67(3), 265–276.
- Klar, B. (2015).** *A Note on Gamma Difference Distributions*. Journal of Statistical Computation and Simulation, 85(18), 3708–3715.
- R Core Team (2018).** *R: A language and environment for statistical computing*. R Foundation for Statistical Computing, Vienna, Austria.
URL <https://www.R-project.org/>.
- Štulajter, F. (2002).** *Predictions in Time Series Using Regression Models* (Springer).
- Štulajter, F. (2003).** *The MSE of the BLUP in a Finite Discrete Spectrum LRM*. Tatra Mountains Mathematical Publications, 26(1), 125–131.
- Štulajter, F., Witkovský, V. (2004).** *Estimation of variances in orthogonal finite discrete spectrum linear regression models*. Metrika, 60(2), 105–118.

Uďaka za pozornosť

Definícia (NE), Hančová (2008)

Uvažujme pre pozorovanie \mathbf{X} ČR $X(\cdot)$ CLRM. Odhadca $\check{y}(\mathbf{X}) = (\check{\sigma}^2(\mathbf{X}), \check{\sigma}_1^2(\mathbf{X}), \dots, \check{\sigma}_l^2(\mathbf{X}))$ sa nazýva prirodzený odhadca, ak:

$$\check{\sigma}^2(\mathbf{X}) = \frac{1}{n - k - l} [X - F\hat{\beta}(\mathbf{X}) - V\hat{y}(\mathbf{X})]' [X - F\hat{\beta}(\mathbf{X}) - V\hat{y}(\mathbf{X})],$$

$$\check{\sigma}_j^2(\mathbf{X}) = \hat{y}_j(\mathbf{X})^2, \quad j = 1, 2, \dots, l,$$

kde $(\hat{\beta}(\mathbf{X}), \hat{y}(\mathbf{X}))' = (\hat{\beta}_1(\mathbf{X}), \dots, \hat{\beta}_k(\mathbf{X}), \hat{y}_1(\mathbf{X}), \dots, \hat{y}_l(\mathbf{X}))'$ je odhad regresného parametra $(\beta, \mathbf{y})' \in \mathbb{E}^{k+l}$ metódou najmenších štvorcov.

Definícia (DOOLSE, MDOOLSE), Štulajter, Witkovský (2004)

Nech je daný lineárny regresný model

$$\mathbf{X} = \mathbf{F}\boldsymbol{\beta} + \boldsymbol{\varepsilon}; \mathbf{F} \in \mathbb{E}^{n \times k}, \boldsymbol{\beta} \in \mathbb{E}^k, E\{\boldsymbol{\varepsilon}\} = 0, \text{Cov}\{\mathbf{X}\} = E\{\boldsymbol{\varepsilon}\boldsymbol{\varepsilon}'\} = \boldsymbol{\Sigma}, \boldsymbol{\Sigma} \geq 0,$$

ktorého kovariančná matica $\boldsymbol{\Sigma} = \boldsymbol{\Sigma}_{\boldsymbol{\nu}}$; $\boldsymbol{\nu} \in \Upsilon \subset \mathbb{E}^l$, je parametrizovaná pomocou parametra $\boldsymbol{\nu}$. Pre ľubovoľnú realizáciu \mathbf{x} vektora \mathbf{X} sú definované odhady DOOLSE a MDOOLSE parametra $\boldsymbol{\nu}$ nasledovne:

$$\text{DOOLSE} \quad \tilde{\boldsymbol{\nu}}(\mathbf{x}) = \arg \min_{\boldsymbol{\nu} \in \Upsilon} \|\mathbf{S}(\mathbf{x}) - \boldsymbol{\Sigma}_{\boldsymbol{\nu}}\|^2,$$

$$\text{MDOOLSE} \quad \hat{\boldsymbol{\nu}}(\mathbf{x}) = \arg \min_{\boldsymbol{\nu} \in \Upsilon} \|\mathbf{S}(\mathbf{x}) - \mathbf{M}_{\mathbf{F}}\boldsymbol{\Sigma}_{\boldsymbol{\nu}}\mathbf{M}_{\mathbf{F}}\|^2,$$

kde matica $\mathbf{S}(\mathbf{x})$ je daná $\mathbf{S}(\mathbf{x}) = (\mathbf{x} - \mathbf{F}\hat{\boldsymbol{\beta}})(\mathbf{x} - \mathbf{F}\hat{\boldsymbol{\beta}})'$; $\mathbf{M}_{\mathbf{F}} = \mathbf{I} - \mathbf{F}(\mathbf{F}'\mathbf{F})^{-1}\mathbf{F}'$; \mathbf{x} je realizácia \mathbf{X} a $\hat{\boldsymbol{\beta}}$ je odhad parametra $\boldsymbol{\beta}$ metódou najmenších štvorcov (OLSE)

$$\hat{\boldsymbol{\beta}}(\mathbf{x}) = \arg \min_{\boldsymbol{\beta} \in \mathbb{E}^k} \|\mathbf{X} - \mathbf{F}\boldsymbol{\beta}\|^2.$$

Gama rozdielové rozdelenie – $GDD(\alpha_1, \beta_1, \alpha_2, \beta_2)$, Klar (2015)

- hustota rozdelenia

$$f(z) = \begin{cases} ce^{\beta_2 z} \int_z^\infty x^{\alpha_1-1} (x-z)^{\alpha_2-1} e^{-(\beta_1+\beta_2)x} dx, & z > 0 \\ ce^{-\beta_1 z} \int_{-z}^\infty x^{\alpha_2-1} (x-z)^{\alpha_1-1} e^{-(\beta_1+\beta_2)x} dx, & z < 0 \end{cases}; c = \frac{\beta_1^{\alpha_1} \beta_2^{\alpha_2}}{\Gamma(\alpha_1)\Gamma(\alpha_2)}$$

$$f(z) = \begin{cases} \frac{\tilde{c}}{\Gamma(\alpha_1)} z^{\frac{\alpha_1+\alpha_2}{2}-1} e^{\frac{\beta_2-\beta_1}{2}z} W_{\frac{\alpha_1-\alpha_2}{2}, \frac{1-\alpha_1-\alpha_2}{2}}((\beta_1+\beta_2)z), & z > 0 \\ \frac{\tilde{c}}{\Gamma(\alpha_2)} (-z)^{\frac{\alpha_1+\alpha_2}{2}-1} e^{\frac{\beta_1-\beta_2}{2}(-z)} W_{\frac{\alpha_2-\alpha_1}{2}, \frac{1-\alpha_1-\alpha_2}{2}}((\beta_1+\beta_2)(-z)), & z < 0 \end{cases}$$

$$\tilde{c} = \frac{\beta_1^{\alpha_1} \beta_2^{\alpha_2}}{(\beta_1 + \beta_2)^{\frac{\alpha_1+\alpha_2}{2}}} \quad W_{k,m} - \text{Whittakerova funkcia}$$

- momentová vytvárajúca a distribučná funkcia

$$M_X(t) = \left(1 - \frac{t}{\beta_1}\right)^{-\alpha_1} \left(1 + \frac{t}{\beta_2}\right)^{-\alpha_2}, \quad |t| < \min\{\beta_1, \beta_2\}$$

$$F(t) = d \int_{\max\{0, -t\}}^\infty x^{\alpha_2-1} e^{-\beta_2 x} \gamma(\alpha_1, \beta_1(x+t)) dx, \quad t \in \mathbb{E}$$

- stredná hodnota a disperzia

$$\mu = \frac{\alpha_1}{\beta_1} - \frac{\alpha_2}{\beta_2}, \quad \sigma^2 = \frac{\alpha_1}{\beta_1^2} + \frac{\alpha_2}{\beta_2^2}$$

NE

$$\check{\sigma}^2(\mathbf{X}) \sim \Gamma\left(\frac{n-k-l}{2}, \frac{n-k-l}{2\sigma^2}\right)$$

$$\check{\sigma}_j^2(\mathbf{X}) \sim \Gamma\left(\frac{1}{2}, \frac{1}{2(\sigma^2 \mathbf{W}_{jj}^{-1} + \sigma_j^2)}\right)$$

MNE

$$\check{\sigma}^2(\mathbf{X}) \sim \Gamma\left(\frac{n-k-l}{2}, \frac{n-k-l}{2\sigma^2}\right)$$

$$\check{\sigma}_j^2(\mathbf{X}) \sim GDD(\alpha_1, \beta_1, \alpha_2, \beta_2)$$

$$\text{s parametrami } \alpha_1 = \frac{1}{2}, \beta_1 = \frac{1}{2(\sigma^2 \mathbf{W}_{jj}^{-1} + \sigma_j^2)}, \alpha_2 = \frac{n-k-l}{2}, \beta_2 = \frac{n-k-l}{2\sigma^2 \mathbf{W}_{jj}^{-1}}$$

DOOLSE

$$\check{\sigma}^2(\mathbf{X}) \sim \Gamma\left(\frac{n-k-l}{2}, \frac{n-l}{2\sigma^2}\right)$$

$$\check{\sigma}_j^2(\mathbf{X}) \sim GDD(\alpha_1, \beta_1, \alpha_2, \beta_2)$$

$$\text{kde } \alpha_1 = \frac{1}{2}, \beta_1 = \frac{1}{2(\sigma^2 / \|\mathbf{v}_j\|^2 + \sigma_j^2)}, \alpha_2 = \frac{n-k-l}{2}, \beta_2 = \frac{(n-l)\|\mathbf{v}_j\|^2}{2\sigma^2}$$

MDOOLSE

$$\check{\sigma}^2(\mathbf{X}) \sim \Gamma\left(\frac{n-k-l}{2}, \frac{n-k-l}{2\sigma^2}\right)$$

$$\check{\sigma}_j^2(\mathbf{X}) \sim GDD(\alpha_1, \beta_1, \alpha_2, \beta_2)$$

$$\text{kde } \alpha_1 = \frac{1}{2}, \beta_1 = \frac{1}{2(\sigma^2 / \|\mathbf{v}_j\|^2 + \sigma_j^2)}, \alpha_2 = \frac{n-k-l}{2}, \beta_2 = \frac{(n-k-l)\|\mathbf{v}_j\|^2}{2\sigma^2}$$